



TITLE:

ニューロイダルネットとコネクショニズム：「脳を創る」ための計算機科学からのアプローチ (離散的アルゴリズムと計算量)

AUTHOR(S):

西野, 哲朗

---

CITATION:

西野, 哲朗. ニューロイダルネットとコネクショニズム：「脳を創る」ための計算機科学からのアプローチ (離散的アルゴリズムと計算量). 数理解析研究所講究録 1998, 1054: 1-10

ISSUE DATE:

1998-07

URL:

<http://hdl.handle.net/2433/62284>

RIGHT:

# ニューロイダルネットとコネクショニズム —「脳を創る」ための計算機科学からのアプローチ—

西野哲朗  
電気通信大学 電子情報学科

## 1 「脳を創る」ためには

現在、さまざまな角度から脳機能の研究が行われている。心理学、言語学、人工知能、認知科学などの研究者は、脳機能をマクロレベルから考察しているのに対し、脳科学研究者はミクロレベルから、ニューラルネット研究者は中間レベルからの考察を行っていると考えられる。これらの研究は、すべてそれぞれのレベルからの真理探求の試みであり、どれも傾聴に値する。

人工的に「脳を創る」ためには、これらすべての努力を統合することを試みるのが、科学の発展過程としても自然である。ところが、このような統合の試みは従来ほとんど行われていない。その理由のひとつとして考えられるのは、統合のための枠組みの欠如である。我々は、そのような枠組みとして、最近 L. G. Valiant によって導入されたニューロイダルネット [8, 9, 10] が有望であると考えている。

脳機能のマクロレベルの研究には、心理学、言語学、人工知能、認知科学などがある。これらの分野には、言語、記憶、学習、思考などに関する研究成果が多い。しかし、一般に記述のレベルが粗過ぎて、例えば、具体的な学習プロセスなどをうまく表現できない。これに対して脳機能のミクロレベルの研究には脳科学などがあり、この分野には、脳の構造、記憶などに関する研究成果が多い。ミクロレベルの研究では、記述のレベルが細か過ぎて全体像が理解できないため、マクロな脳機能をミクロレベルで記述することは事実上不可能と思われる。

一方、脳機能の中間レベルの研究においては、ニューラルネット、ニューロイダルネットなどが用いられる。ニューラルネット研究は、視覚、聴覚、運動、記憶などの分野で成功を収めている。しかし、言語、思考などの高次な脳機能に関しては、あまり成果が得られていない。ニューロイダルネットはニューラルネットの一般形であり、ニューラルネットの動作はすべてニューロイダルネットの動作として記述可能である。また、ニューロイダルネット上では、前提条件に基づく学習、暗記学習などが自然な形で表現できる。また、しきい値回路設計の技法を用いて、マクロな脳機能のシミュレーションも行える。

本稿では、言語獲得のモデル化を例として、ニューロイダルネット上における高次脳機能のモデル化の基本的考え方を説明する。また、高次脳機能のモデル化に関する研究の今後の構想についても述べる。なお本研究では、実際の脳と入出力関係や計算時間などがほぼ等しいニューロイダルネットの構築を目指している。したがって、各ニューロイドと脳内の各脳細胞の間には、一般に 1 対 1 の対応関係はない。(そのような対応関係があれば、ミクロレベルのモデルとなる。) しかし、各ニューロイドが脳細胞群と対応する形の抽象化が行われている可能性はある。

## 2 ニューロイダルネット

本節では、まず L. G. Valiant が提案したニューロイダルネットの定義を述べる。ニューロイダルネットとは、ニューロイドと呼ばれる素子から構成される回路（ネットワーク）である。ニューロイドとは、通常のしきい値論理素子に状態を付加し、その状態やしきい値、辺の重み等の更新を関数で指定することにより、しきい値論理回路上の学習を記述できるようにしたモデルである。

**定義 2.1** [8] ニューロイダルネットとは、以下の条件を満たす 6 項組  $N = (G, W, Q, X, \delta, \lambda)$  のことをいう。

1.  $G$  は  $N$  のトポロジーを記述する有向グラフ。  $G$  の頂点と辺の集合をそれぞれ  $V$ ,  $E$  と表す（すなわち  $G = (V, E)$ ）。以下では、 $|V| = n$  のときには  $V = \{1, 2, \dots, n\}$  と表記する。  $V$  の要素（  $G$  の頂点）をニューロイドと呼ぶ。また、ニューロイド  $j$  から  $i$  に向かう辺を、  $(j, i)$  と書くことにする。
2.  $W$  は  $G$  の辺が持つことができる重みの集合。  $G$  の辺  $(j, i) \in E$  の重みを  $w_{ji}$  を記す。
3.  $Q$  は各ニューロイド（  $V$  の要素）が取ることができる状態の有限集合。
4.  $X$  は各ニューロイドのモードの集合。ここで、ニューロイド  $i \in V$  のモード  $s_i$  とは、  $Q \times \mathbf{Z}^\gamma$  の要素のことをいう。ただし、  $\mathbf{Z}$  は整数全体の集合とし、  $\gamma \geq 1$  は定数とする。すなわち  $s_i$  は、状態  $q_i \in Q$  と、ベクトル  $T = (T_i^1, T_i^2, \dots, T_i^\gamma) \in \mathbf{Z}^\gamma$  の組  $[q_i, T]$  である。ここで、  $T_i^1$  を特にニューロイド  $i$  のしきい値といい、通常  $T_i$  と記す。
5.  $\delta$  は以下の型のモード更新関数。

$$\delta(s_i, w_i) = s'_i$$

ただし、  $w_i$  は発火している（1 を出力している）ニューロイド  $j$  から  $i$  への辺の重みの総和である。ニューロイド  $j$  の出力を  $f_j$  で表すことにすると、  $w_i$  は以下の式で定義される。

$$w_i = \sum_{f_j=1 \wedge (j,i) \in E} w_{ji}$$

すなわち  $\delta$  は、ニューロイド  $i$  の現在のモード  $s_i$  と、その時点に  $i$  に到達した重みの総和  $w_i$  にしたがって、  $i$  の新しいモードを指定する関数である。

6.  $\lambda$  は以下の型の重み更新関数。

$$\lambda(s_i, w_i, w_{ji}, f_j) = w'_{ji}$$

すなわち  $\lambda$  は、ニューロイド  $i$  の現在のモード  $s_i$  と、その時点に  $i$  に到達した重みの総和  $w_i$ 、辺  $(j, i)$  の現在の重み  $w_{ji}$ 、および、ニューロイド  $j$  の出力  $f_j$  にしたがって、辺  $(j, i)$  の新しい重みを指定する関数である。  $\square$

ニューロイダルネット  $N$  の動作は、以下の  $IC$  と  $IS$  を指定すると完全に決定される。

- (a)  $N$  のモードと重みの初期値  $IC$ 。




Figure 1: 簡単なニューロイダルネットワーク  $N_1$ .

- (b) 外部から直接コントロールされる  $N$  内のニューロイドの発火のタイミング  $IS$ . このようなニューロイドの発火のタイミングには, 入力系列の与え方 ( $N$  の入力素子の発火のタイミングのコントロール) も含まれているが, それ以外に, ニューロイダルネットワークでは Prompt という命令 (以下の例を参照) を用いて, 特定のニューロイドを任意のタイミングで直接発火させることができる. これは, 末梢神経により直接コントロールされるニューロンの発火をモデル化したものである.

例 2.1 文献 [8] に示されている簡単なニューロイダルネットワーク  $N_1 = (G, W, Q, X, \delta, \lambda)$  を以下に示す. まず,  $G = (V, E)$ ,  $V = \{1, 2, 3, 4, 5\}$ ,  $E = \{(1, 5), (2, 5), (3, 5), (4, 5)\}$  である. また,  $W = \{0, 1\}$ ,  $Q = \{A1, A2\}$ ,  $X = Q \times N$  (すなわち  $\gamma = 1$ ) とする. このとき, モード更新関数  $\delta$  は以下のように定義される.

$$\delta([A1, T_i], w_i) = [A2, w_i] \text{ for all } T_i, w_i$$

また, 重み更新関数  $\delta$  は以下のように定義される.

$$\lambda([A1, T_i], w_i, w_{ji}, 0) = 0 \text{ for all } T_i, w_i, w_{ji}$$

このように定義されたニューロイダルネットワーク  $N_1$  が, 時刻  $t$  に図 1 左に示されたような様相にあったとする. すなわち, そのように  $IC$  と  $IS$  が指定されていたとしよう. このとき, 更新関数  $\delta$  と  $\lambda$  が適用されると,  $N_1$  は時刻  $t+1$  に図 1 右のような様相に変化する.

このような更新関数の適用の結果, これ以後  $N_1$  内のニューロイド 5 は, ニューロイド 1 と 3 が同時に発火したときにのみ発火するようになる. この意味で, ニューロイド 5 はニューロイド 1 と 3 で表された概念の連言 (AND) を学習したと考えることができる.

ニューロイダルネットワークの 2 つの更新関数  $\delta$  と  $\lambda$  をまとめて記述するための略記法が, Valiant 自身により提案されている [8]. 例えば, 上の例の更新関数は, 以下のように略記される.

Step 1 : Prompt: 1, 3.

$$\{q_i = A1\} \Rightarrow \{q_i := A2, T_i := w_i, \text{ if } f_i = 0 \text{ then } w_{ji} := 0\}.$$

上で示された  $\{...\} \Rightarrow \{...\}$  の形の規則を、条件付き更新規則という。条件付き更新規則の左辺は、対応する更新に必要な条件を記述し、また右辺には左辺の条件が成立したときの、モードと重みの更新操作を記述する。ここで、左辺の条件が時刻  $t$  で成り立つならば、右辺で規定された更新は時刻  $t+1$  に行われるものとする。

ニューロイダルネット上の更新作業は、上のようなステップの系列によってアルゴリズムとして記述される。ここで、各ステップは、いくつかの条件付き更新規則と、それに先立つ 1 つの **Prompt** 文からなる。Prompt 文は、ニューロイダルネット内の特定のニューロイドの集合を発火させるための命令文である。例えば、上の例の “Prompt: 1, 3.” という Prompt 文は、 $N_1$  内のニューロイド 1 と 3 を同時に発火させよという命令を表している。

### 3 前提条件に基づく学習

脳の高次機能解明のためには、ニューロイダルネットを用いて脳のミクロ・レベルのモデルを記述しても、おそらくあまり効果はない（脳のミクロ・レベルのモデルにおいては、各ニューロイドは脳内の 1 つのニューロンと対応する）。だからと言って、脳のマクロ・レベルのモデルを記述してもうまく行かないことは、人工知能研究の歴史が示している。そこで我々は、ニューロイダルネットによる、脳の間レベルのモデルの構築を目指している。例えば、以下で示す言語認識のモデル化で用いるニューロイダルネットにおいては、各ニューロイドが 1 つの品詞などに対応している。

このような中間レベルのモデル化は、従来、認知心理学のなかのコネクショニズムにおいて行われてきた。したがって我々の立場は、コネクショニズムの新たなモデルとして Valiant のニューロイダルネットを採用しているとも見られる。

前提条件に基づく学習（precondition-based learning）の基本的な考え方は、

$$(\text{前提条件}) + (\text{学習}) = (\text{知識})$$

と表現できる。すなわち、ある知識を獲得する際には、そのための前提条件が巧妙であればあるほど、学習は簡単になるということである。

一般に、自然言語は文脈自由言語よりも複雑であろうと予想されている。さらに、母国語の文法知識を獲得する際には、幼児は言語の正のサンプルしか用いていないということが、言語学者の間で主張されている。一方、計算論的学習理論における Gold の結果は、正のサンプルだけからでは、正則言語でさえ学習不可能であることを述べている。ただし、この場合の学習は白紙状態からの学習である。すなわち、前提条件に基づく学習の図式において、前提知識が空である白紙状態からの学習では、正のサンプルだけからでは、文脈自由以上の複雑さを持つ自然言語の文法知識は獲得できないと考えられる。

Chomsky の普遍文法理論 [2] の基本的な考え方は、

$$(\text{普遍文法}) + (\text{学習}) = (\text{個別文法})$$

と表現することができる。すなわち、母国語の文法知識の獲得には、普遍文法という前提知識が存在すると主張している。このような前提知識を仮定した学習においては、その前提知識の設定の仕方によっては、非常に複雑な言語の文法であっても、正のサンプルのみから学習可能になる。逆の見方をすれば、人間の自然言語の文法知識の獲得においては、なんらかの前提知識が必要であることを Gold の結果は主張している。

従来、計算論的学習理論の研究においては、このような前提知識に基づく学習アルゴリズムの設計はあまり行われてこなかった。これまでの計算論的学習理論の研究成果は、主に計算機に概念を効率的に学習させることに関係しており、人間の学習過程を説明するた

めの知見はあまり得られていない。ニューロイダルネット上の前提条件に基づく学習の目標は、人間の種々の記憶や学習の過程を、できるだけ現実に忠実な形でモデル化することにある。

そのためには、学習に先立って脳内に存在している前提条件そのものをモデル化しなければならない。ニューロイダルネット上における学習では、

(前提条件) = (初期回路)

と考える。人間の脳内には、この初期回路に当たる構造が、例えば遺伝子情報などにしたがつて先天的に構築されていると考える。このような初期回路の構成は、言語学、認知心理学等の学説、実験データなどを参考にしながら行う。

## 4 言語認識知識の獲得のモデル化

Chomsky の GB 理論 [1, 2, 5] によれば、例えば英語は、名詞句 *the man in the park* , 動詞句 *walk very slowly* , 前置詞句 *to the girl* などに見られるように、句の主要部（名詞句の場合には名詞）が補部の前に現れるので、ヘッド前置と呼ばれる。これに対し日本語は、名詞句「公園にいるその男」、動詞句「非常にゆっくり歩く」、前置詞句「少女に」などに見られるように、句の主要部が補部の後に現れるので、ヘッド後置と呼ばれる。

Chomsky によれば、普遍文法に含まれるヘッド・パラメータは、母国語の正のサンプルだけからヘッド前置またはヘッド後置に設定される。この他にも普遍文法内にはいくつかのパラメータが存在し、それらが母国語データによって設定されると、その母国語に対する個別文法が得られると考えられている。

図 2 に、我々が言語認識の知識獲得をモデル化するために構成した初期回路を示す [7]。この初期回路は、入力部、動作部、パラメータ設定部からなる。この回路では、入力部を通して与えられる言語の正のサンプルを、動作部が状態遷移を行いながら認識し、それがヘッド前置であるかヘッド後置であるかを判定する。十分多数の入力文に対するこのような判定結果に基づいて、パラメータ設定部がヘッド・パラメータを設定し、その値にしたがつて動作部の構造を、ヘッド前置またはヘッド後置の文の認識のみが行えるように変化させる（このような動作部の辺の重みの更新作業は、図 3 に示した更新規則に基づいて行われる）。例えば、図 2 の初期回路に正しい英文（英語の正のサンプル）を十分に数多く与えると、ヘッドパラメータはヘッド前置に設定され、それにしたがつて動作部は、ヘッド前置の文のみを認識するように辺の重みが固定化される。

図 2 の初期回路上の、言語認識知識獲得のための学習アルゴリズムの一部を図 3 に示す。まず、入力部内の状態が **Comp**, **XP**, **Spec**, **X** のニューロイドは、それぞれ与えられた入力部が補部、指定部、限定詞、主要部のときに発火する。すなわち本論では、入力された語が上のどの範疇の要素であるかは、別の回路で判定されているものと仮定している。

動作部の状態が **Ini** のニューロイドはサンプルの入力時に発火し、**Out** のニューロイドは入力終了時に発火する。状態が **RC**, **RXP**, **RS**, **RX** のニューロイドは、それぞれ **Comp**, **XP**, **Spec**, **X** が入力されたときに発火する。さらに、これらの状態のニューロイドにおいては、そのモードの第 2 成分が 2 次元ベクトルであると仮定する。すなわち、 $s_i = [q_i, (T_i^1, T_i^2)]$  である。ただし、 $T_i^1$  はしきい値、 $T_i^2$  は学習の終了判定に用いる数である。状態 **JC**, **JX** のニューロイドは、それぞれ状態 **RC**, **RX** のニューロイドが発火したときに発火する。また、状態 **AC**, **AX** のニューロイドは、それぞれ **Comp**, **X** が先に入力されたときに発火する。状態 **Judge** のニューロイドは、文法的に正しい文が入力されたときにのみ発火する。状態 **HPS\_First** のニューロイドは、**Comp** が **X** よりも先に入力




Figure 2: 言語認識知識獲得のための初期回路.

**Step 0:**  $\{w_i \geq 6\} \Rightarrow \{q_i := q_i M\}$ .

**Step 1:** Prompt: **IniM**.

$$\begin{aligned} &\{q_i = \text{RSM}(\text{RXM}), w_i < 4\} \Rightarrow \\ &\quad \{\text{if } f_j = 1 \text{ then } w_{ji} := w_{ji} + 0.2\} \\ &\{q_i = \text{RSM}(\text{RXM}), w_i \geq 4\} \Rightarrow \\ &\quad \{q_i := \text{RSM}'(\text{RXM}'), T_i := T_i^{(2)}\} \\ &\{q_i = \text{IniMF}\} \Rightarrow \{q_i = \text{Ini}\}. \end{aligned}$$

**Step 2:** Prompt: **RSM, RSM'**.

$$\begin{aligned} &\{q_i = \text{RXM}, w_i < 4\} \Rightarrow \\ &\quad \{\text{if } f_j = 1 \text{ then } w_{ji} := w_{ji} + 0.2\} \\ &\quad \vdots \end{aligned}$$

Figure 3: ヘッド・パラメータ設定アルゴリズム.

され、かつ文法的に正しい文が入力されたときにのみ発火する（すなわちヘッド前置の入力文に対して発火する）。同様に、状態 **HPS\_Last** のニューロイドはヘッド後置の入力文に対して発火する。

図 3 のヘッド・パラメータ設定のためのアルゴリズムは、状態 **HPS\_First** または **HPS\_Last** のニューロイドが発火したときに起動され、それぞれの場合に、ヘッド前置またはヘッド後置の句の認識で用いられるすべての辺の重みを若干増加させる。このような処理を多数のサンプルに対して繰り返すうちに、どこかのニューロイド  $i$  に伝わる重みの総和が  $T_i^2$  以上になったならば、必要なニューロイドのモードや辺の重みを変化させ、ヘッド・パラメータが設定された状態に回路を変化させる。

## 5 拡張ニューロイダルネット

冒頭でも述べたように、人間の脳機能をモデル化する研究は、脳科学、心理学、計算機科学などの多くの分野で、さまざまな手法を用いて行われている。例えば、脳科学における画期的成果として、小脳内の前庭動眼反射学習機構は、神経回路網モデルのパーセプトロンを用いて直接モデル化できることが知られている。この場合、パーセプトロンは脳のミクロレベルのモデルを与えていると考えることができる。

これに対し、いわゆるコネクショニストモデルは、情報の分散表現に基づいて心理学的現象を説明する脳の中間レベルのモデルである。コネクショニストモデルは、1970 年代後半から、心理学者が神経回路網モデルと類似の構造を持つ分散表現モデルとして研究を始めたもので、このモデルの説明対象は、心理学、行動科学における現象である。分散表現



に基づくモデルは、連想、パターンの学習、行動の学習において起こる、部分からの全体の想起、ノイズが含まれている場合の想起などの現象を説明しやすい。

一方、脳のマクロレベルのモデルとしては、情報の局所表現に基づく記号処理モデルがある。一般に、思考や言語に関連した記号的情報の記憶、学習を説明するには、コンピュータプログラムのような記号処理モデルを用いた方が有効なことが多い。現在までのところ、思考や言語に関する多くの問題は、コネクショニストモデルで取り扱うのが大変困難である。たとえコネクショニストモデルで表現できたとしても、複雑なわりに記号処理モデルで説明できる以上のことを説明できていないという批判がある。しかし、思考や言語に関する問題のなかにも、不完全情報の取り扱いや、部分からの全体の連想など、記号処理モデルでは説明が困難なものがある。

一般に、記号処理モデルは「硬い」モデルであり、コネクショニストモデルは「柔らかい」モデルであると考えられている。また、上で述べたように、これら2つのモデルは、それぞれに適した対象分野を持っている。そこで、これら2つのモデルの長所をともに利用して、脳のモデリングを行う方法は考えられないであろうか？

一方で、人間の脳は思考や言語に関する問題を、並列計算メカニズムを用いて統一的に処理している。人間の認知機能をなんらかの方法でモデル化した場合、そのモデルの妥当性を評価するには、例えば、その認知機能のモデル上での実行時間と、人間の実際の実行時間とを比較する方法が考えられる。しかし、このような比較が行えるためには、認知機能のモデル化を並列計算モデルを用いて行う必要がある。

そこで以下では、コネクショニストモデルと記号処理モデルの両方の長所を合わせ持った並列計算モデルとして、拡張ニューロイダルネットを提案する。

## 5.1 拡張ニューロイダルネットの定義

拡張ニューロイダルネットの定義の基礎となるニューロイダルネットは、基本的には脳のミクロレベルのモデルとして定式化された。拡張ニューロイダルネット(Extended Neurodal Net, 以下 ENN と略す)は、オラクルゲートの使用を許したニューロイダルネットである。オラクルゲート  $O$  が実行する計算  $Comp(O)$  は、ニューロイダルネットまたはアルゴリズムを用いて任意に定義してよいものとする。オラクルゲート  $O$  のサイズ  $size(O)$  と深さ  $depth(O)$  を以下のように定義する。

1.  $Comp(O)$  をニューロイダルネット  $C$  で定義した場合には、 $size(O)$  と  $depth(O)$  は、それぞれ  $C$  のサイズと深さとする。
2.  $Comp(O)$  をアルゴリズム  $A$  で定義した場合には、 $size(O)$  と  $depth(O)$  は、それぞれ  $A$  の計算を模倣するニューロイダルネットのサイズと深さとする。
3.  $n$  入力  $m$  出力のオラクルゲート  $O_n^m$  のサイズと深さのデフォルト値は、 $size(O) = 1$ ,  $depth(O) = \lceil \log n \rceil$  とする。この場合には、重要なパラメータである深さだけを定義している。

ENN における計算は、オラクルゲート  $O$  において、そのゲートに割り当てられた計算  $Comp(O)$  を実行する以外は、通常のニューロイダルネットにおける計算とまったく同様に行われる。ただし、ENN のサイズと深さは、各オラクルゲート  $O$  についてのみ、そのサイズと深さを、それぞれ  $size(O)$ ,  $depth(O)$  として評価する。

## 5.2 拡張ニューロイダルネットの機能

実際的には、オラクルゲートは、コネクショニストモデル上における情報隠ぺいの機能を果たす。大規模な回路の設計図を一度に見せられても、回路の全体的な構造は理解できない。そこで最初は、オラクルゲートを多用した抽象度の高い ENN を見ることで回路の全体的な機能を把握し、その後に、各オラクルゲートにおける処理を詳細を見ていくことで、回路全体が行う計算を、回路の構造に従って詳細化しながら把握していくことができる。

また、例えば GB 理論に基づく文生成のように、記号処理プログラムで記述した方が、はるかにわかり易い処理については、その処理をオラクルゲートに割り当て、処理の内容は適当なプログラムで指定しておくことができる。一方、連想記憶のようなコネクショニストモデルの方がうまく説明できる認知機能については、ニューロイダルネット本来の表現法でそのまま記述しておけばよい。

このように ENN の動作は、コネクショニストモデルで用いられるニューロイダルネットと、記号処理モデルで用いられるアルゴリズムの両方を混在させる形で定義できる。オラクルゲートにおける計算がニューロイダルネットとして定義されている場合には、そのゲートは主に、回路の全体像をとらえやすくするための情報隠ぺいの役目を果たしている。一方、オラクルゲートにおける計算がアルゴリズムで定義されている場合には、そのゲートは情報隠ぺいの役目の他に、そのゲートにおいて局所的な並列計算が行われることを、サブルーチンコールのような形で表現している。

ENN の動作時間は、その（回路としての）深さに対応させて評価する。したがって、ENN の全体としての動作は、オラクルゲートで指定されているアルゴリズムをすべてそれを模倣するニューロイダルネットに変換したときに得られる、ニューロイダルネットの動作として並列的にとらえていることになる。

## 6 展望

本稿で述べてきたように、ニューロイダルネットの主な利点としては、以下のものが考えられる。

1. ニューロイダルネットは、脳機能に関するマクロからミクロまでのすべてのレベルの研究成果を統一的に記述できる、ちょうど良い粒度（中間レベル）のモデルである。
2. ミクロからマクロまでの脳機能をすべてニューロイダルネット上でシミュレーションできれば、種々の脳機能を「学習をとまなう計算」として統一的に表現でき、さらに、画像、音声、言語などの種々の情報が自然な形で統合処理できる。

今後、図 4 に掲げた脳機能を、拡張ニューロイダルネット上のブール演算として統一的に実現していきたいと考えている。なお、運動、注意と意識、情動は、現在の研究の対象外としている。

仮に、人間の脳細胞が 1000 億個あったとする。そのうちの割（100 億個）が実際に活動していたとして、脳の複製係数を 100 とすれば、全脳機能を模倣するニューロイダルネットの素子数はおよそ 1 億個となる。現在研究対象にしている脳機能に話を限定すれば、素子数はその割の 1000 万個ほどで足りるのではないか？この規模の並列シミュレーションは、10 年以内には可能になるのではないかと思われる。

Valiant は、現在広く用いられている効率的計算のモデルは、人間の脳が実際に行っていることのモデル化には直接使用できないであろうという主旨のことを述べている [9]。今

脳機能	参考となる研究
言語認識	拡張遷移ネットワーク (Woods [11])
構文論	統率・束縛理論 (Chomsky [1])
意味論, 運用論	Cognitive Grammar (Langacker [4])
言語獲得	統率・束縛理論 (Chomsky [1])
戦略の学習	人工知能研究 (Khardon [3] など)
概念学習	連言, 選言, しきい値関数, 関係などの学習 [8]
思考 (推論)	人工知能研究 (Roth [6] など)
記憶	ニューラルネットワーク研究. ニューロイダルネットの hashing 特性の研究 [8].
視覚	ニューラルネットワーク研究.
聴覚	ニューラルネットワーク研究.

Figure 4: ニューロイダルネット上での実現を目指す脳機能と, その参考となる研究.

後, 計算機科学者が認知科学や脳科学などとの境界領域において研究を進めることにより, 人間の高次脳機能の数学的モデルを構築していくべきであろう.

## References

- [1] Chomsky, N. : *Lectures on Government and Binding : The Pisa Lectures*, Dordrecht, Foris, 1986.
- [2] Cook, V. J. : *Chomsky's Universal Grammar : An Introduction*, Basil Blackwell Ltd., 1988 (日本語訳:「チョムスキーの言語理論 - 普遍文法入門 -」, 須賀哲夫訳, 新曜社).
- [3] Khardon, R. : "Learning to Take Actions", *Proc. of AAAI96* (1996), pp.787-792.
- [4] Langacker, R. W. : *Foundations of Cognitive Grammar, Vol.I Theoretical Prerequisites*, Stanford University Press, 1987.
- [5] 中村・金子・菊池:「生成文法の基礎 - 原理とパラミターのアプローチ -」, 研究社出版, 1989.
- [6] Roth, D. : "A Connectionist Framework for Reasoning : Reasoning with Examples", *Proc. AAAI97* (1997), pp.1256-1261.
- [7] 内田勝也, 西野哲朗:「ニューロイダルネット上における自然言語の学習について」, 1997 年度人工知能学会全国大会講演論文集.
- [8] Valiant. L. G. : *Circuits of the Mind*, Oxford University Press, 1994.
- [9] Valiant. L. G. : "Cognitive Computation", *Proc. 36th FOCS* (1995), pp.2-3.
- [10] Valiant. L. G. : "Managing Complexity in Neuroidal Circuits", *Proc. COLT96* (1996), pp.1-11.
- [11] Woods, W. : "Transition Network Grammars for Natural Language Analysis", *CACM*, Vol.13 (1970), pp.591-606.